

비예약 접속 시스템을 위한 딥러닝 기반 프리앰블 설계

한민식^o, Ameha T. Abebe 강충구
고려대학교 전기전자공학과

Deep learning-based Preamble Design for Grant-free Multiple Access System

Min S. Han^o, Ameha T. Abebe, and Chung G. Kang

*Korea University

{als4585, ameha_tsegaye, ccgkang}@korea.ac.kr

요약

상향링크 대규모 비예약 접속 시스템에서는 프리앰블(preamble)을 통한 활성 사용자 검출기(active user detection: AUD)가 설계되어야 한다. 이를 위해 채널 오토인코더(autoencoder: AE)를 사용한 딥러닝 기반 프리앰블 및 AUD 설계방식이 제안되었다. 이때, 오토인코더의 학습을 위해 어떤 채널이 적합한지, 즉 AWGN 또는 flat Rayleigh fading 중에서 어떤 채널을 고려할지 결정해야 할 것이다. 예를 들어, AWGN 채널에서 학습을 수행하면 오토인코더의 학습은 용이하지만, 실제로 Rayleigh 채널에서 동작할 때 성능이 열화 될 수 있다. 반면, Rayleigh 채널에서는 프리앰블 디자인을 위한 효율적인 학습 자체가 불가능할 수 있다. 본 논문에서는 두 가지 다른 채널을 통해 설계된 프리앰블의 특성과 성능을 살펴보고, 시스템 설계에서 고려할 점을 도출하고자 한다.

I. 서론

Grant-free sparse codebook multiple access (GF-SCMA) 시스템을 통해 다수의 Internet-of-Things (IoT) 기기들이 동일한 자원에서 예약 없이 저지연으로 다중 접속을 시도할 수 있다[1]. 이를 위해 동시에 접속을 시도할 때 수신단에서는 활성화된 사용자들을 구분하는 활성 사용자 검출(active user detection; AUD)이 수행되어야 한다. 전송된 프리앰블에 대한 AUD 절차를 통해 어떤 기기가 데이터를 전송했는지 알 수 있기 때문에, 이후 개별 사용자에게 대해 채널 추정과 데이터 수신 절차를 수행할 수 있다.

[1]-[2]에서는 채널 오토인코더를 활용하여, AWGN 채널에서 프리앰블 및 AUD 를 함께 설계하는 방식이 제안된 바가 있다. 본 논문에서는, 기존에 AWGN 에서 설계된 기존 제안 방식을 Rayleigh 채널으로 확장하여 검증하기 위해, 가능한 여러가지 학습 방식에 대해 기존의 평균 교차상관관계(average cross-correlation)를 통한 프리앰블 설계 성능 및 활성 사용자 검출 성공 확률을 통한 AUD의 성능을 확인하고자 한다.

II. 시스템 모델

사용자 N 명이 J 개의 코드북 $\bar{C}=\{C_0, C_1, \dots, C_{J-1}\}$ 중 하나를 선택하여 데이터를 전송하는 GF-SCMA 시스템을 기본 모델로 고려한다. n 번째 사용자는 round-robin 형태로 $v(n)=\text{mod}(n, J)$ 번째 코드북을 선택하며, 각 사용자는 자신의 코드북에서 $K^{(d)}$ 차원의 M -ary 코드워드 중 하나를 선택하여 $\log_2 M$ 비트의 데이터를 전송한다. 이때, 충돌을 고려하지 않은 프리앰블 집합의 디자인을 위해, 각 N 명의 사용자는 각자 $\|\mathbf{p}_n\|_2=1$ 인 고유한 프리앰블 $\mathcal{P}=\{\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{N-1}\}$ 을 갖는다고 가정한다. 이때 사용자는 데이터와 함께 프리앰블도 $K^{(p)}$ 개의 자원을 사용하여 동시에 기지국에 전송한다. 사용자 n 의 데이터 코드워드와 파일럿을 각각 $\mathbf{w}_i^{v(n)}$ 과 \mathbf{p}_n 로 나타낸다. 사용자 n 이 N_d 개의 코드워드를 전송한다면 이를 $[\mathbf{p}_n | \mathbf{w}_0^{v(n)}, \mathbf{w}_1^{v(n)}, \dots, \mathbf{w}_{N_d-1}^{v(n)}]$ 로 나타내고, 이를 하나의 경쟁 전송 단위(contention transmission unit: CTU)라고 지칭한다[1].

n 번째 사용자의 트래픽은 p_n 의 활성 확률에 의해 발생한다고 가정하고, 따라서 활성 여부는 Bernoulli 분포를 따르는 활성 지시자 $\delta_n \sim \text{Bern}(p_n)$ 로 나타낼 수 있다. 따라서, 전체 시스템의 CTU 전송 여부는 활성

벡터 $\boldsymbol{\delta}=[\delta_0, \delta_1, \dots, \delta_{N-1}]^T$ 로 나타낼 수 있다(즉, $\delta_n=1$ 이면 CTU 의 전송 상태를, $\delta_n=0$ 이면 전송하지 않음). 이에 따라, 사용자들에 의한 중첩된 프리앰블과 데이터는 각각 다음과 같이 표현된다.

$$\mathbf{y}^{(p)} = \sum_{n=0}^{N-1} \delta_n h_n \mathbf{p}_n + \mathbf{n}^{(p)}, \quad (1)$$

$$\mathbf{y}_i^{(d)} = \sum_{n=0}^{N-1} \delta_n h_n \mathbf{w}_i^{v(n)} + \mathbf{n}_i^{(d)}, i=1, 2, \dots, N_d. \quad (2)$$

이때, \mathbf{n} 은 가산성 가우시안 잡음이며, h_n 은 사용자 n 의 채널 이득을 나타낸다.

III. 활성 사용자 검출 및 프리앰블 디자인

기지국의 수신단에서는 $\mathbf{y}^{(p)}$ 를 통해 AUD 를 수행하여 활성 사용자 벡터 $\hat{\boldsymbol{\delta}}=[\hat{\delta}_1, \hat{\delta}_2, \dots, \hat{\delta}_J]^T$ 를 검출함으로써 어떤 사용자가 CTU 를 전송했는지 알게 된다. 이때, AUD 는 $g(\cdot)$ 의 네트워크를 통해 수행되며, 이에 대한 설계는 다음의 문제로 정식화 된다.

$$g^* = \arg \min_g \|\hat{\boldsymbol{\delta}} - g(\cdot; \boldsymbol{\theta}^{(g)})\|_0 \quad (3)$$

이때, (1)만을 고려한 preamble-based AUD network (AUDN)은 $\hat{\boldsymbol{\delta}} = g_1(\mathbf{y}^{(p)}; \boldsymbol{\theta}^{(g_1)})$ 로 표현할 수 있고, (1)과 (2)를 모두 이용하는 data-aided AUDN 은 $\hat{\boldsymbol{\delta}} = g_2(\mathbf{y}^{(p)}, \{\mathbf{y}_i^{(d)}\}_{i=1}^{N_d}; \boldsymbol{\theta}^{(g_2)})$ 로 표현할 수 있다. 여기서 $\boldsymbol{\theta}^{(g_1)}$ 와 $\boldsymbol{\theta}^{(g_2)}$ 는 각각의 학습 가능한 weight 와 bias 이다. 각 AUDN 의 자세한 네트워크 구조와 학습 방식은 [1]의 설명을 참조한다.

한편, AUD 를 위한 프리앰블 집합 \mathcal{P} 를 설계 문제는 다음과 같이 문제를 정식화 할 수 있으며,

$$\min_{\mathcal{P}} \max_{0 \leq i \neq j \leq N-1} \frac{|\langle \mathbf{p}_i, \mathbf{p}_j \rangle|}{\|\mathbf{p}_i\|_2 \|\mathbf{p}_j\|_2} \quad (4)$$

여기서 $|\langle \cdot, \cdot \rangle|$ 는 두 벡터간 교차 상관관계(cross-correlation) 값이다[3]. (4)에 의해 설계된 프리앰블의 성능을 평가하는 기준 metric 으로서, 각 프리앰블 i 의 평균 교차상관값 $\mu_{i, \text{avg}}$ 를 정의할 수 있다[4].

$$\mu_{i, \text{avg}} = \frac{1}{N-1} \sum_{j=1, j \neq i}^N |\langle \mathbf{p}_i, \mathbf{p}_j \rangle| \quad (5)$$

만약, $\mu_{i, \text{avg}}$ 는 각 프리앰블이 프리앰블 세트 내 다른 프리앰블과의 상대적인 상관 관계를 나타내는 척도로서, (4)의 최적화를 통해 프리앰블 간의 상대적인 상관값이 최소화가 되도록 프리앰블을 설계하게 된다.

III. 제안 방식의 딥러닝 기반 디자인 요소

[1]-[2]의 제안 방식에서 프리엠프와 AUD 설계에서 어떤 형태의 채널을 고려하는지, 그리고 제약 조건과 구현 방식에 따라 다양한 설계 방식이 존재할 수 있다. 이를 요약하면 표 1에서 보는 16 가지 가능한 설계 방식이 될 수 있다. 여기서, AUD를 위해 프리엠프만 사용하거나(preamble-based AUD) [4] 또는 프리엠프와 데이터를 동시에 사용할 수 있다(data-aided AUD) [3]. 한편 프리엠프를 (4)의 최적화를 만족시키도록 독립적으로 설계할지 아니면, (4)를 위반하지만 data-aided AUD에 적합하도록 AUD와 동시에 설계할 것인지 여부를 고려할 수 있다. 한편, 딥러닝을 통해 수신단의 AUD를 설계할 때도 AWGN 채널을 가정할지 또는 Rayleigh 채널을 가정할지 선택할 수 있다.

표 1. 설계 방식에 따른 분류

Preamble Design	Channel	AWGN	Rayleigh
	Type	Independent	Joint
AUD Design	Channel	AWGN	Rayleigh
	Type	Preamble-based	Data-aided AUD

IV. 시뮬레이션 결과

$N = 60$ 명의 사용자가 고유의 프리엠프를 갖고, 모든 사용자의 활성 확률이 0.05 이라고 가정한다. 이때 $K^{(p)} = 16$ 길이의 프리엠프를 사용하며, 각 사용자는 $J = 6$ 및 $K^{(d)} = 4$ 를 갖는 SCMA 코드북을 사용한다. 제안 방식의 자세한 학습 방식 및 hyperparameter는 [1]을 참조한다. 본 논문에서는 프리엠프 생성에 적합한 방식을 선택하고자 하기 때문에 프리엠프를 생성을 위해 고려할 수 있는 표 1과 같이 4 가지 경우의 수를 모두 고려하며, 이에 대한 성능과 특성을 분석한다. 다만, AUD의 Rayleigh 채널에서의 학습만을 가정한다. 또한 AUD는 기본적으로 preamble 기반이 아닌 data-aided AUD를 가정하지만 비교군으로써 case 1에 대해서만 preamble-based AUD를 가정한다.

표 2. 설계 방식에 따른 분류

	Preamble Design		AUD Design	
	Channel	Type	Channel	Type
Case 1	Rayleigh	Independent	Rayleigh	Preamble-based
Case 2	Rayleigh	Joint		Data-aided
Case 3	AWGN	Independent		
Case 4	AWGN	Joint		

그림 1(a)와 (b)는 표 2에서 제시한 4 가지 프리엠프 설계 방식에 대해서 각 프리엠프의 평균 교차 상관관계를 나타낸 것이다. 검정색과 초록색 그래프는 Rayleigh 채널에서 생성한 프리엠프들의 평균 교차 상관관계를 나타내고, 빨간색과 파란색 그래프는 AWGN에서 생성한 프리엠프들의 평균 교차 상관관계를 나타낸다. Rayleigh 채널에서 생성한 프리엠프의 최대 평균 교차상관관계가 AWGN 채널에서 생성한 프리엠프보다 더욱 큰 것을 알 수 있다. 이는 프리엠프 학습을 위한 오토인코더가 Rayleigh 채널의 위상 변화로 인해 AWGN에 비해 안정적으로 수렴되지 않음을 의미한다.

그림 2에서는 Rayleigh 채널에서 활성 사용자 검출 성공 확률을 나타낸다. SNR 15dB 이하의 영역에서는, 검정색과 초록색 그리고 빨간색과 파란색 그래프를 각각 비교하면, 독립적인 프리엠프 설계를 통해 성능이 향상된다는 것을 알 수 있다. 이는 잡음이 커서 활성 사용자 검출 오류가 많이 나는 경우 (4)를 위반하도록 동시에 프리엠프를 설계하는 것 보다, (4)를 만족하도록, 즉 최대 교차 상관관계를 최소화하도록, 독립적으로

프리엠프를 설계하는 것이, 검출 오류를 결정하는 worst performance 프리엠프가 잡음에 더욱 강인해지도록 만들기 때문이다.

한편, 15dB 이상에서는 검정색 그래프와 나머지 세 그래프를 비교했을 때 preamble-based AUD 보다 data-aided AUD를 사용했을 때 최대 활성 사용자 검출 성능이 더 우수한 것을 알 수 있다. 이때, data-aided AUD를 사용했을 때는 프리엠프를 동시에 설계한 것이나 독립적으로 설계한 것이나 성능 차이가 거의 없음을 알 수 있다. 즉, [2]에서 AWGN에서 확인한 1dB 성능 이득이 Rayleigh 채널로 오면서 거의 사라졌음을 확인하였다.

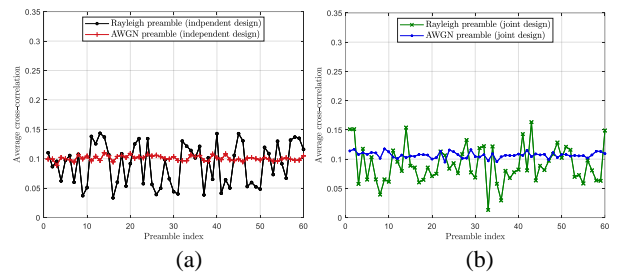


그림 1. 평균 교차 상관 관계 (a) independent design (b) joint design

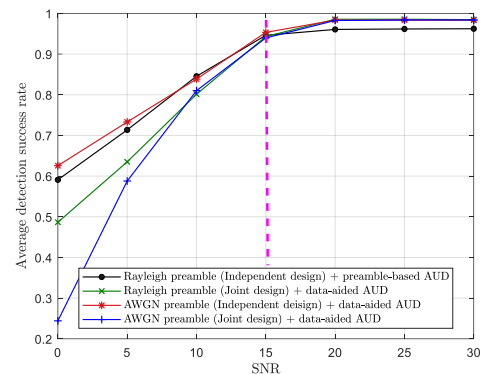


그림 2. 활성 사용자 검출 성공 확률

V. 결론

본 논문에서는 GF-SCMA 시스템을 위한 딥러닝 기반 AUD 방식에서 활성 사용자 검출 성공 성능을 시뮬레이션을 통해 분석하였다. 낮은 SNR에서 AWGN 채널을 가정하고 프리엠프를 AUD와 별개로 독립적으로 설계하는 것이 가장 좋은 성능을 보였다. AUD는 Rayleigh 채널에서 설계되어야 하며, 이때 높은 SNR 영역에서는 data-aided AUD를 통해 성능을 향상시킬 수 있음을 확인하였다.

ACKNOWLEDGMENT

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No.2021-0-00467, 지능형 6G 무선 액세스 시스템)

참고 문헌

- [1] M. Han, A. T. Abebe and C. G. Kang, "Data-aided Active User Detection with a User Activity Extraction Network for Grant-free SCMA Systems," arXiv Preprint, May. 2022, arXiv:2205.10780
- [2] M. Han, A. T. Abebe and C. G. Kang, "On the Performance of Deep Learning-based Data-aided Active User Detection for GF-SCMA System," arXiv Preprint, Aug. 2022, arXiv: 2208.08128
- [3] G. Li, Z. Zhu, D. Yang, L. Chang and H. Bai, "On Projection Matrix Optimization for Compressive Sensing Systems," *IEEE Transactions on Signal Processing*, vol. 61, no. 11, pp. 2887-2898, June, 2013.
- [4] N. Kim, D. Kim, B. Shim and K. B. Lee, "Deep Learning-Based Spreading Sequence Design and Active User Detection for Massive Machine-Type Communications," *IEEE Wireless Communications Letters*, vol. 10, no. 8, pp. 1618-1622, Aug. 2021